



**Makale / Research Paper**

**Çöz Aktar İşbirlikli Çeşitlemeli Çok Röleli Sistemlerde Derin Öğrenme Yardımlı En İyi Röle Seçimi ve Güç Optimizasyonu**

**Ahmet EMİR<sup>1a\*</sup>, Ferdi KARA<sup>1b</sup>, Hakan KAYA<sup>1c</sup>**

<sup>1</sup> Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü,  
Zonguldak/TÜRKİYE  
ahmet.emir@beun.edu.tr

**Received/Geliş:** 09.06.2021

**Accepted/Kabul:** 13.12.2021

**Öz:** İşbirlikli Haberleşme sistemi kaynak, röleler ve hedef düğümlerden oluşmaktadır. Kaynak, işaretleri rölelere ve hedefe, röleler ise çözdüğü işareti hedef düğüme aktarmaktadır. İşbirlikli haberleşme sistemlerinde spektral verimliliğin korunması açısından en iyi röle seçimi önemli bir husustur. Ayrıca güvenli bir iletişim için kaynak röle ve röle hedef düğümleri arasındaki işaret gürültü oranlarının da maksimum yapılması gereklidir. Diğer taraftan, derin öğrenme (deep learning-DL) tekniği fiziksel seviye haberleşme tekniklerinde yaygın olarak kullanılmaya başlanan bir tekniktir. DL var olan haberleşme tekniklerine alternatif çözümler sunmaktadır. Bu çalışmada DL tekniği en iyi röle seçimi için kullanılmıştır. En iyi röle seçiminde, kaynaktan-röle ve röle-hedef arasında iletim yapılırken güç optimizasyonu da göz önünde bulundurulmuştur. Evrişimli sinir ağı (Convolutional Neural Network-CNN) tekniği ile bulunan sonuçlar geleneksel maxmin yöntemi ile tespit edilen en iyi röle ile bulunan sonuçlardan hata performansı açısından başarılıdır. Ayrıca DL ile hata başarımlarına güç optimizasyonu da önemli bir etki sağlamaktadır.

**Anahtar Kelimeler:** CNN, BPSK, DF, İşbirlikli Haberleşme, Derin Öğrenme.

**Best Relay Selection and Power Optimization in Deep Learning Aided Multi-Relay System with Decode and Forward Cooperative Diversity**

**Abstract:** Cooperative Communication system consists of source, relays and destination nodes Source transmits signals to relays and target node, and relays transmit the decoded signals to the target node. The best relay selection is an important issue in terms of maintaining spectral efficiency in cooperative communication systems. In addition, for a secure communication, it is necessary to maximize the signal-to-noise ratios between the source relay and relay destination nodes. Moreover, Deep learning (DL) technique has been a technique that have been widely used among physical level communication techniques. DL proposes alternative solutions to existing communication techniques. In this study, the best relay has been selected with DL technique. Best relay selection has been implemented by considering power optimization while transmitting from source to the best relay and transmitting between the best relay and target node. The results obtained with the Convolutional Neural Network (CNN) technique are more successful in terms of error performance than the results found with the best relay detected by the traditional maxmin method. In addition, power optimization also has a significant effect on error performance with DL.

**Keywords:** CNN, BPSK, DF, Cooperative Communication, Deep Learning.

**1. Giriş**

Kablosuz haberleşme sistemleri, sisteminin performansını etkileyen sönümlenme ve girişim gibi ciddi etkilere maruz kalmaktadır. Bu etkiler nedeniyle sistem hata performansı, kesinti olasılığı ve iletim çıkış hızı olumsuz etkilenebilmektedir [1]. İşbirlikli haberleşme, ortama dağıtılmış düğümleri

*Bu makaleye atıf yapmak için*

Emir, A., Kara, K., Kaya, H., "Çöz Aktar İşbirlikli Çeşitlemeli Çok Röleli Sistemlerde Derin Öğrenme Yardımlı En İyi Röle Seçimi Ve Güç Optimizasyonu" El-Cezeri Fen ve Mühendislik Dergisi 2022, 9(1); 144-158.

*How to cite this article*

Emir, A., Kara, F., Kaya, H., "Best Relay Selection And Power Optimization In Deep Learning Aided Multi-Relay System With Decode And Forward Cooperative Diversity" El-Cezeri Journal of Science and Engineering, 2022, 9(1); 144-158.

ORCID ID: \*0000-0001-8038-2747; <sup>0</sup>0000-0001-9735-5200; <sup>0</sup>0000-0003-4390-5363

kullanarak çeşitleme kazancı sağlamaktadır. İşbirlikli çeşitleme kazancı, doğrudan kaynak hedef düğüm arasındaki haberleşme bağlantısının yanında kaynak düğümünden hedef düğüme rölelerin kullanılmasıyla sağlanmaktadır. İşbirlikli çeşitleme sağlanırken farklı performans değerleri literatürde incelenmiştir. Çift atlamalı kanalda Rayleigh [2], Rician [3] ve Nakagami-m [4] kanallarında hata performansları incelenmiştir. [5]'de Nakagami-m ve Rayleigh sönümlenmeli kanalda tek röleli işbirlikli haberleşme sisteminde kesinti olasılığı incelenmiştir. [6]'da ise iki yönlü röleli sistemin çıkış hızı performansı iyileştirilmektedir.

İşbirlikli rölenin spektral verimliliğini artırmak için en iyi rölenin seçilmesi önemli bir durumdur. Böylelikle var olan kaynaklar etkin bir şekilde kullanılmaktadır [7]. Rayleigh sönümlenmeli kanalda en iyi rölenin seçildiği durumda hata olasılığı, kesinti olasılığı ve kanal kapasitesi kapalı form teorik çözümlerine [8]'de yer verilmiştir. [9]'da çöz aktar (decode forward - DF) protokolü kullanan en iyi N. rölenin seçilmesi durumunda hata performansı ve kesinti olasılığının analitik ve benzetim çözümlerine yer verilmiştir. [10]'da ise benzer çözümler kuvvetlendir aktar (amplify forward-AF) röleli sistem için sunulmuştur. [11]'de ise hata yayılımı durumunda N adet röle arasından en iyi rölenin seçildiği durum için hata performans eğrileri verilmiştir. Çoklu röleli sistemlerde en iyi röle seçiminden sonra kaynaktan toplam gücün seçilen röle(ler) ve kaynağa ne kadarının optimum şekilde paylaşılacağını belirlemek önemli bir güç atama problemidir. [12]'de çok röleli DF işbirlikli haberleşme sisteminde güç atama yapılarak tüm düğümler arasındaki yollardaki en düşük veri hızının da maksimum yapılması hedeflenmiştir. [13]'te ise benzer güç optimizasyonu çoklu giriş çoklu anten (multiple input multiple output-MIMO)'lere sahip DF rölelerden oluşan sistemde araştırılmıştır. [14]'de ise kaynak ve dinleyici kaynağın olduğu tek röleli sistemde kaynak ve röle arasında optimum güç paylaşımına karar verilmiştir. Ayrıca işbirlikli haberleşme literatürde 5. nesil haberleşme (fifth generation-5G) sistemleri için öncü olacağı düşünülen diğer teknolojilerle de beraber uygulanmaktadır. [15,16]'da dikgen olmayan çoklu erişim (non orthogonal multiple access-NOMA), [17]'de indis modülasyonu (index modulation -IM) ve milimetre dalga haberleşmesinde (mmWave Communication) [18] işbirlikli haberleşme ile beraber kullanılmıştır.

Son yıllarda, haberleşme sistemlerinde artan işlem karmaşıklığının azaltılması ve basit optimizasyon çözümleri sunması açısından makine öğrenim yöntemlerinden biri olan derin öğrenme (deep learning-DL) ağları kullanımı yaygınlaşmaktadır. DL ağlarına evrişimli sinir ağları (convolutional neural network-CNN), uzun kısa dönem hafıza (long short term memory- LSTM), derin öğrenme takviyeli (deep reinforcement learning-DRL), otomatik kodlayıcı (autoencoders-AE), üretken rakip ağlar (generative adversarial nets-GAN) örnek gösterilebilmektedir. [19]'da kullanılan haberleşme kanalı GAN'lar ile tasarlanmıştır. [20] 'de dikgen frekans bölmeli çoğullama (orthogonal frequency division multiplexing-OFDM) işaret sezimi ve kanal kestirimi için LSTM kullanılmıştır. [21]'de CNN ile modülasyon sınıflandırması gerçekleştirilmiştir. DRL'ye [22]'te kaynak atama optimizasyonu için başvurulmuştur. [23]'te ise Rayleigh ve toplanır beyaz Gauss gürültüsü (additive white Gaussian noise-AWGN) alanında akıllı rasgele blok uzunluğu sunan AE sistemi önerilmiştir. Ayrıca DL ağları NOMA [24-26], IM [27] ve mmWave [28] gibi güncel teknolojilerde de kullanılmıştır. İşbirlikli haberleşme sistemleri de literatürde DL ağlar kullanarak tasarlanmıştır [29,30]. Yakın kullanıcının röle, uzak kullanıcının hedef düğüm olduğu işbirlikli haberleşme ve NOMA teknolojisinin var olduğu bir sistemde sinyal sezimi için LSTM ağlarından faydalanılmıştır [31]. DL aynı zamanda, 6G tabanlı nesnelerin interneti (internet of things-IoT) ağlarında veri toplamak için uygulanmaktadır [32]. [33]'te, kablosuz iletişim ağında gizli dinleyicilerin hâlihazırda var olduğu çok sayıda meşru kullanıcının iletişimini garanti altına almak için DRL tabanlı akıllı yüzey önerilmiştir. Gelecekte 6G ağlarda da akıllı kaynak yönetimi için DL ağlar kullanılması öngörülmektedir [34].

Bu çalışmada ise çok röleli ortamda güç optimizasyon tabanlı CNN yardımcı en iyi röle seçimi önerilmiştir. Önerilen DL ağı, kaynak düğümünden röle düğüme optimum güç atamasını da dikkate

olarak kaynak röle ve röle hedef düğümünden en iyi röleyi seçmektedir. Ayrıca geleneksel maxmin yöntemi ile de en iyi röle seçimi yapılmıştır. İşbirlikli haberleşmede DL ağıyla bulunan röle seçilmesi durumundaki hata performansı, maxmin yöntemi ile en iyi röle seçilmesi durumundaki hata performansı ile karşılaştırılmıştır. Ayrıca eğitilenden farklı röle sayısında ve farklı kanal güçlerinde en iyi röle seçildiğindeki hata performansı incelenmiştir.

## 2. Maxmin En İyi Röle Seçim Yöntemi

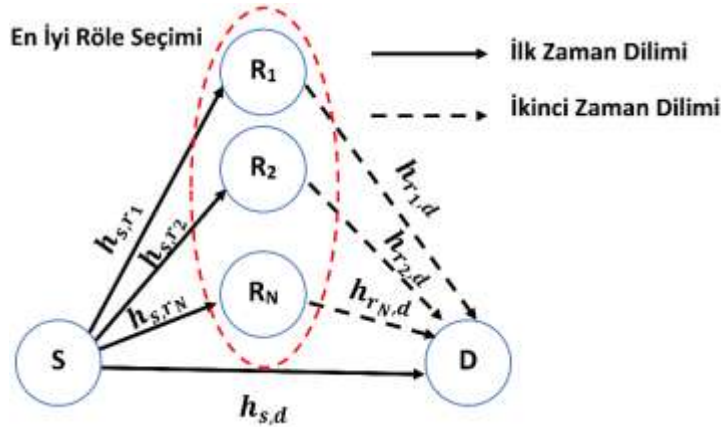
Şekil 1’de bir adet kaynak düğüm (S), bir adet hedef düğüm (D) ve N adet röleden ( $R_i$ ,  $i=1, 2, \dots, N$ ) oluşan işbirlikli haberleşme sistemi verilmiştir. Röleler DF protokolüne göre çalışmaktadır. Gelen işareti çözerek hedefe aktarmaktadır. Birinci zaman diliminde D ve  $i$ . röle  $R_i$ ’ye gelen işaretler:

$$y_{sd} = \sqrt{P\eta}h_{sd}x + n_{sd},$$

$$y_{sr_i} = \sqrt{P\eta}h_{sr_i}x + n_{sr_i}$$

ile ifade edilmektedir.

P toplam iletim gücünü,  $\eta$  ilk zaman diliminde toplam iletim gücünün kaynaktan ne kadarının kullanıldığını gösteren güç katsayısını,  $h_{sd}$ ,  $h_{sr_i}$  sırasıyla kaynak ve hedef arasındaki  $\sigma_{sd}^2$  varyanslı sıfır ortalamalı ve kaynak ile  $i$ . röle arasındaki  $\sigma_{sr_i}^2$  varyanslı sıfır ortalamalı düz Rayleigh kanal katsayılarını göstermektedir.  $h_{sd}$  ve  $h_{sr_i}$  birbirlerinden istatistiksel bağımsızdır.  $n_{sd}$  ve  $n_{sr}$  ise sıfır ortalamalı  $N_0/2$  varyanslı toplanır beyaz gauss gürültüsü (additive white Gaussian Noise- AWGN) katsayılarını göstermektedir.  $x$ , birinci zaman diliminde kaynaktan gönderilen ikili faz kaydırmalı anahtarlama (binary phase shift keying – BPSK) modülasyonlu temel bant sembolleridir. Geleneksel maxmin en iyi seçim algoritmasında  $\eta = 0.5$  seçilmektedir.



Şekil 1. Geleneksel Maxmin En İyi Röle Seçim Yöntemi

İkinci zaman diliminde, seçilen en iyi röle DF ile çözdüğü işareti hedef düğümüne aktarmaktadır. En iyi röle ise, kaynak-röle ve röle-hedef arasındaki anlık işaret gürültü oranlarından (signal to noise ratio-SNR) en iyi SNR değerlerini veren röleye göre seçilir. Klasik maxmin yönteminde en iyi röle seçimi:

$$\lambda_{sel} = \max_{i \in N} \{ \min(\lambda_{s,r_i}, \lambda_{r_i,d}) \}$$

ile bulunur.  $\lambda_{sel}$  ile en iyi anlık SNR değerlerini veren  $\lambda_{s,r_i}$  ve  $\lambda_{r_i,d}$  seçilir. Bu değerleri sağlayan röle de seçilen en iyi röledir.  $\lambda_{s,r_i}$  ve  $\lambda_{r_i,d}$  sırasıyla kaynak ile  $i$ . röle arasındaki anlık SNR ve  $i$ . röle ve kaynak arasındaki anlık SNR’dir.  $\lambda_{s,r_i}$  ve  $\lambda_{s,r_i}$ ,

$$\lambda_{s,r_i} = |h_{sr_i}|^2 \frac{P\eta}{N_0}$$

$$\lambda_{r_i,d} = |h_{r_i,d}|^2 \frac{P(1-\eta)}{N_0}$$

ile verilir.  $h_{rid}$ , i. röle ile kaynak arasındaki  $\sigma_{rid}^2$  varyanslı sıfır ortalamalı düz Rayleigh kanal katsayılarını göstermektedir.  $|\cdot|$  mutlak değer işlevidir. Seçilen röle için birinci zaman diliminde röleyle gelen işaret;

$$y_{r_{sel}} = \sqrt{P\eta}h_{sr_{sel}}x + n_{sr_{sel}}$$

ile ifade edilmektedir. İkinci zaman diliminde seçilen röleden kaynağa iletilen işaret:

$$y_{r_{sel},d} = \sqrt{P(1-\eta)}h_{r_{sel},d}\hat{x} + n_{r_{sel},d}$$

olur.  $\hat{x}$ , birinci zaman diliminde seçilen rölede en büyük olasılıklı sezici (Maximum Likelihood Detector- MLD) ile sezilen BPSK modülasyonu temel bant sembolleridir:

$$\hat{x} = \underset{j}{\operatorname{argmin}} |y_{r_{sel}} - \sqrt{P\eta}h_{s,r_{sel}}x_j|^2, j = 1, 2, \dots, M$$

$x_j$ , seçilen rölenin M'li modülasyon sırasının j. yıldız küme(constellation) noktalarıdır. BPSK için M=2 seçilmiştir. Hedef düğümde iki zaman dilimindeki işaretler en büyük olasılık birleştirme (Maximum Ratio Combining- MRC) kullanılarak birleştirilir:

$$y_d = y_{sd}h_{sd}^* + y_{r_{sel},d}h_{r_{sel},d}^*$$

### 3. Önerilen CNN Modeli

Önerilen CNN modeli ile kaynak-röle ve röle-hedef düğüm arasındaki anlık kanal katsayıları eğitilerek en iyi rölenin seçimi hedeflenmiştir. En iyi röle seçimi yapılırken optimum güç atama da göz önünde bulundurulmuştur. Kanal katsayıları matris haline getirilmiştir. CNN, giriş matrisinden öznelik çıkartma kabiliyetinden ötürü tercih edilmiştir. CNN ağları ilk kez LeCun tarafından geliştirilen LeNet [35]'de kullanılmıştır. Bu çalışmada önerilen CNN yardımcı sistem modeli Şekil 2'de gösterilmiştir.

CNN modeli, konvolüsyon katmanı, maksimum havuzlama (maxpooling) ve iki adet tam bağlı katman (FC-Fully Connected Layer) içermektedir.

CNN girişine uygulanan H matrisi, anlık SNR bilgilerinin yanı sıra iletilen toplam gücün ne kadarının ( $\eta$ ) birinci zaman diliminde kaynaktan kullanıldığını ve ne kadarının  $(1-\eta)$  ikinci zaman diliminde rölede kullanıldığı bilgisini de içermektedir. Böylelikle en iyi röle bulunurken güç atama kriteri de dikkate alınmaktadır. Sistemde N adet röle mevcut olduğu durumda belirli bir aralıktaki güç oranlarına göre tüm  $h_{sr_i}$  ve  $h_{r_i,d}$  varyasyonları üretilerek H matrisi oluşturulmaktadır. H matrisinde kanal katsayıları  $\sqrt{\eta}h_{sr_i}$  ve  $\sqrt{(1-\eta)}h_{r_i,d}$  şeklinde elde edilmiştir. Güç paylaşım katsayısının hassasiyetinin etkisinin incelenmesi amacıyla  $\eta_1=[0.2:0.2:0.8]$  ve  $\eta_2=[0.1:0.1:0.9]$ 'e göre iki farklı durumda H matrisi üretilmiştir. Dolayısıyla iki farklı veri seti elde edilerek iki ayrı eğitim yapılacaktır.  $\eta_1$  durumundaki H<sub>1</sub> matrisi ve  $\eta_2$  durumundaki H<sub>2</sub> matrisi:

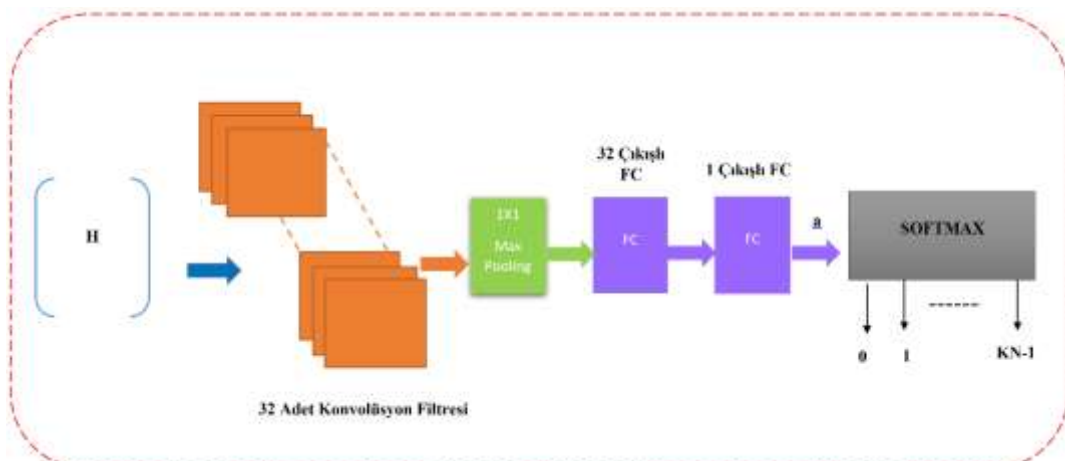
$$H_1 = \begin{bmatrix} \sqrt{0.2}gerçel(h_{sf_1}) & \sqrt{0.2}sanal(h_{sf_1}) & \sqrt{0.8}gerçel(h_{rd}) & \sqrt{0.8}sanal(h_{rd}) \\ \sqrt{0.4}gerçel(h_{sf_1}) & \sqrt{0.4}sanal(h_{sf_1}) & \sqrt{0.6}gerçel(h_{rd}) & \sqrt{0.6}sanal(h_{rd}) \\ \sqrt{0.6}gerçel(h_{sf_1}) & \sqrt{0.6}sanal(h_{sf_1}) & \sqrt{0.4}gerçel(h_{rd}) & \sqrt{0.4}sanal(h_{rd}) \\ \sqrt{0.8}gerçel(h_{sf_1}) & \sqrt{0.8}sanal(h_{sf_1}) & \sqrt{0.2}gerçel(h_{rd}) & \sqrt{0.2}sanal(h_{rd}) \\ \sqrt{0.2}gerçel(h_{sf_2}) & \sqrt{0.2}sanal(h_{sf_2}) & \sqrt{0.8}gerçel(h_{rd}) & \sqrt{0.8}sanal(h_{rd}) \\ \dots & \dots & \dots & \dots \\ \sqrt{0.8}gerçel(h_{sf_2}) & \sqrt{0.8}sanal(h_{sf_2}) & \sqrt{0.2}gerçel(h_{rd}) & \sqrt{0.2}sanal(h_{rd}) \\ \dots & \dots & \dots & \dots \\ \sqrt{0.2}gerçel(h_{sf_N}) & \sqrt{0.2}sanal(h_{sf_N}) & \sqrt{0.8}gerçel(h_{rd}) & \sqrt{0.8}sanal(h_{rd}) \\ \sqrt{0.4}gerçel(h_{sf_N}) & \sqrt{0.4}sanal(h_{sf_N}) & \sqrt{0.6}gerçel(h_{rd}) & \sqrt{0.6}sanal(h_{rd}) \\ \sqrt{0.6}gerçel(h_{sf_N}) & \sqrt{0.6}sanal(h_{sf_N}) & \sqrt{0.4}gerçel(h_{rd}) & \sqrt{0.4}sanal(h_{rd}) \\ \sqrt{0.8}gerçel(h_{sf_N}) & \sqrt{0.8}sanal(h_{sf_N}) & \sqrt{0.2}gerçel(h_{rd}) & \sqrt{0.2}sanal(h_{rd}) \end{bmatrix} \quad (8)$$

$$H_2 = \begin{bmatrix} \sqrt{0.1}gerçel(h_{sf_1}) & \sqrt{0.1}sanal(h_{sf_1}) & \sqrt{0.9}gerçel(h_{rd}) & \sqrt{0.9}sanal(h_{rd}) \\ \sqrt{0.2}gerçel(h_{sf_1}) & \sqrt{0.2}sanal(h_{sf_1}) & \sqrt{0.8}gerçel(h_{rd}) & \sqrt{0.8}sanal(h_{rd}) \\ \dots & \dots & \dots & \dots \\ \sqrt{0.9}gerçel(h_{sf_1}) & \sqrt{0.9}sanal(h_{sf_1}) & \sqrt{0.1}gerçel(h_{rd}) & \sqrt{0.1}sanal(h_{rd}) \\ \sqrt{0.1}gerçel(h_{sf_2}) & \sqrt{0.1}sanal(h_{sf_2}) & \sqrt{0.9}gerçel(h_{rd}) & \sqrt{0.9}sanal(h_{rd}) \\ \dots & \dots & \dots & \dots \\ \sqrt{0.9}gerçel(h_{sf_2}) & \sqrt{0.9}sanal(h_{sf_2}) & \sqrt{0.1}gerçel(h_{rd}) & \sqrt{0.1}sanal(h_{rd}) \\ \dots & \dots & \dots & \dots \\ \sqrt{0.1}gerçel(h_{sf_N}) & \sqrt{0.1}sanal(h_{sf_N}) & \sqrt{0.9}gerçel(h_{rd}) & \sqrt{0.9}sanal(h_{rd}) \\ \sqrt{0.2}gerçel(h_{sf_N}) & \sqrt{0.2}sanal(h_{sf_N}) & \sqrt{0.8}gerçel(h_{rd}) & \sqrt{0.8}sanal(h_{rd}) \\ \dots & \dots & \dots & \dots \\ \sqrt{0.9}gerçel(h_{sf_N}) & \sqrt{0.9}sanal(h_{sf_N}) & \sqrt{0.1}gerçel(h_{rd}) & \sqrt{0.1}sanal(h_{rd}) \end{bmatrix} \quad (9)$$

ile verilmektedir. CNN karmaşık sayılar üzerinde işlem yapamadığı için anlık karmaşık kanal katsayılarının gerçel ve sanal bileşenleri ayrı ayrı kullanılarak H matrisine atanmıştır.

Konvolüsyon filtresi, H matrisi ile konvolüsyon yaparak öznelik çıkartmaktadır. Şekil 2'den görüleceği üzere 32 adet konvolüsyon filtresi mevcuttur. Yapılan denemeler sonucunda daha fazla sayıda filtre sayısının performansı değiştirmeyeceği için 32 adet filtre sayısında karar verilmiştir.

Aktivasyon fonksiyonu olarak ReLU işlevi kullanılmıştır. ReLU fonksiyonu, herhangi bir negatif girdi alırsa 0 çıktısı vermektedir, ancak herhangi bir pozitif değer girdisi için girdideki değeri çıktı vermektedir.



Şekil 2. CNN Yardımlı Sistem Modeli

Maksimum Havuzlama, matris üzerinden örnek seyrelterek örnek azaltmayı hedeflemektedir. Her bir CNN katmanında 1x1 lik bölgeler seçilerek örnek azaltılmıştır.

CNN katmanlarından sonra kullanılan FC katmanlarına başvurulmaktadır. FC, konvolüsyon çekirdeğinden gelen değerleri rasgele belirlenmiş bir ağırlık matrisi ile çarptıktan sonra rasgele belirlenmiş bir son eşik (bias) eklemektedir. Modelde, biri 32 diğeri 1 çıkışlı olan iki adet FC Katmanı mevcuttur.

En son katman, softmax katmanıdır. Softmax, bir ağın çıktısını çıktı sınıfları üzerinden bir olasılık dağılımına normalleştiren bir işlemdir:

$$f(a)_i = \frac{e^{a_i}}{\sum_j e^{a_j}}$$

Burada a Şekil 2’de softmax işlevinin girişidir.

C sınıf sayısını göstermektedir. C aşağıdaki kümenin bir elemanıdır:

$$C \in \left\{ \underbrace{\vec{0}, \vec{1}, \dots, \vec{K-1}}_{1.röle}, \underbrace{\vec{K}, \dots, \vec{2K-1}}_{2.röle}, \dots, \underbrace{\vec{K(N-1)}, \dots, \vec{KN-1}}_{N.röle} \right\}$$

K güç atama vektörünün ( $\eta_1$  ya da  $\eta_2$ ) boyutunu,  $N$  röle sayısını ifade etmektedir. Her bir röle alt grubundaki  $i_1, i_2, \dots, i_k$  indisi ise  $\eta_1$  ya da  $\eta_2$ ’daki indisini göstermektedir.  $\eta_1$  için sınıflandırıcı kümesi  $N$  röleden oluşan 4 alt gruba ayrılmaktadır.  $\eta_2$  için ise sınıflandırıcı kümesi  $N$  röleden oluşan 9 alt gruba ayrılmaktadır. Seçilen indisten de birinci ve ikinci zaman diliminde toplam güçten ne kadarının iletildiği rahatça bulunabilmektedir.  $\eta_1$  seçildiğinde  $K=4$  olmaktadır. Ortamda da  $N=4$  röle olduğu varsayılırsa CNN  $K \times N = 4 \times 4 = 16$  sınıf üzerinden eğitim yapacaktır.  $\eta_2$  seçildiğinde ise  $K=9$  olmaktadır. Ortamda  $N=4$  röle olduğu varsayılırsa CNN  $K \times N = 4 \times 9 = 36$  sınıf üzerinden eğitim yapacaktır. Örneğin sınıflandırıcı 12 değerini bulmuşsa (11)’e göre  $K(N-1)$  sınıfı tespit edilmiştir.  $N$ .röle alt grubundan olduğu için en iyi röle 4 olarak seçilmiştir. Seçilen indis  $i_1$ , yani  $\eta_1$ ’in birinci indisini göstermektedir.  $\eta_1$ ’in birinci indisi 0.2 olduğu için birinci zaman diliminde seçilen röleye ve hedefe ayrılan gücün toplam gücün 0.2’sinin optimum olarak seçilmesi gerektiğini ifade etmektedir.

Sonrasında veri setinde hedef çıktıları belirtmesi açısından C sınıfının ifade ettiği güç oranlarında maxmin ile de en iyi röle seçilerek 0 ile  $(KN - 1)$  arasında hedef sınıf değeri bulunur. Hedef sınıf değeri  $s_i$  ile ifade edilmektedir. Softmax çıktısı  $f(a)_i$  ile  $s_i$  arasındaki kayıp fonksiyonu kategorisel çapraz entropi ( categorical cross entropy loss-CCE) fonksiyonudur. CCE, mini grup (minibatch size) olarak adlandırılan daha küçük bir alt kümede her iterasyonda ( $l$ )  $s_i$  ile softmax çıkışını karşılaştırmaktadır:

$$CCE(l) = -\sum_i s_i \log(f(a)_i)$$

Stokastik gradyan azalma (stochastic gradient descent-SGD) algoritması, kayıp fonksiyonun negatif gradyanı yönünde her iterasyonda küçük adımlarla ilerleyerek kayıp fonksiyonunu en aza indirmek için ağ parametrelerini (ağırlıklar ve son eşik) günceller:

$$\theta(l+1) = \theta(l) - \mu \nabla CCE(l)$$

Burada  $\Theta$  ağ parametrelerini,  $l$  iterasyonu  $\nabla CCE$  kayıp fonksiyonunun gradyanını,  $\mu$  öğrenme oranını göstermektedir.

### 3.1. Eğitim Algoritması ve Parametre Optimizasyonu

Eğitimde kullanılacak olan veri setini elde etmek için kullanılan algoritma **Algoritma 1**'de verilmiştir. **Basamak 2** 'de Kaynak - i. röle ve i. röle - hedef arasındaki Rayleigh kanal katsayıları güç atama vektörleri ( $\eta_1$  veya  $\eta_2$ ) de dikkate alarak üretilmektedir.

<b>Algoritma 1: Veri Seti Elde Etme</b>	
<b>Veri:</b> S, $\eta_1$ , $\eta_2$ , N, K	
<b>1:</b>	<b>Döngü</b> s=1:S
<b>2:</b>	$\sqrt{\eta_1}h_{sr_i}, \sqrt{(1-\eta_1)}h_{r_i,d}, \sqrt{\eta_2}h_{sr_i}, \sqrt{(1-\eta_2)}h_{r_i,d}$ güç atama vektörlerini dikkate alarak Rayleigh sönümlenmeli kanal katsayılarını üret.
<b>3:</b>	$\eta_1, \eta_2$ için (3)'e göre $\lambda_{s,r_i}$ ve $\lambda_{r_i,d}$ hesapla.
<b>4:</b>	$\eta_1, \eta_2$ için (8) ve (9)'a göre $H_1$ ve $H_2$ matrisini hesapla ve H matrislerini kaydet
<b>5:</b>	$\eta_1, \eta_2$ için (2)'ye göre seçilen rölenin SNR'larından en iyi röleyi seç.
<b>6:</b>	$\eta_1, \eta_2$ için sırasıyla seçilen rölelerin $s_i$ sınıflarını kaydet.
<b>7:</b>	<b>Döngü Bitir</b>

$\eta_1$ 'e göre üretilen kanal katsayıları  $\sqrt{\eta_1}h_{sr_i}, \sqrt{(1-\eta_1)}h_{r_i,d}$ ,  $\eta_2$ 'ye göre üretilen kanal katsayıları  $\sqrt{\eta_2}h_{sr_i}, \sqrt{(1-\eta_2)}h_{r_i,d}$  olmaktadır. S, veri setindeki örnek sayısını göstermektedir.  $\eta_1$  veya  $\eta_2$  için iki ayrı veri seti oluşturulmaktadır. Eğitime gönderilecek giriş veri setleri Basamak 5'teki H matrisleridir. Çıkış veri setleri ise (2) nolu denkleme göre seçilmiş en iyi röleye aktarılan güç oranları da dikkate alınarak 0 ile (KN -1) seçilmiş sınıf değerleridir ( $s_i$ ).

Eğitim algoritması ve parametre optimizasyonu **Algoritma 2** 'de gösterildiği gibidir.  $\eta_1$  veya  $\eta_2$  için ayrı ayrı DL parametreleri tanımlanır. Her bir iterasyonda kayıp fonksiyonu (CCE(I)) hesaplanmaktadır. Eğer önceki iterasyonlara göre maksimum yakınsamaya ulaşılmışsa ağ parametreleri SGD'ye göre güncellenmektedir. Eğitim tamamlandıktan sonra  $\eta_1$  ve  $\eta_2$  için elde edilen ağlar (net) kaydedilmektedir. Çöz aktar çeşitlemeli çok röleli sistemlerde CNN yardımıyla en iyi röle net ağını kullanılarak bulunabilmektedir:

$$s^{dl} = net(H)$$

<b>Algoritma 2: Eğitim Algoritması ve Parametre Optimizasyonu</b>	
<b>Veri:</b> H, $s_i$	
<b>1:</b>	<b>DL parametreleri</b> tanımlanır ( maksimum epoch, öğrenme oranı, mini grup boyutu )
<b>2:</b>	<b>Döngü</b> i=1:e
<b>3:</b>	Her epoch için <b>iterasyonları başlat.</b>
<b>4:</b>	(12)'ye göre mevcut iterasyon için kayıp fonksiyonunu hesapla
<b>5:</b>	<b>Eğer Koşul</b> {Maks [ CCE(I)]}
<b>6:</b>	(13)'e göre epochdaki iterasyon için ağ parametreleri güncellenir. Sonrasında <b>Basamak 4</b> 'e dönülür
<b>7:</b>	<b>Koşul yanlış ise</b>
<b>8:</b>	CCE işlevinde maksimuma yakınsama yoktur. İterasyon artırılır.

- 9: Bitir Eğer**  
**10: İterasyonları bitir.**  
**11: Ağ parametreleri kaydedilir.**  
**12: Bitir Döngü**  
**13: Sonuç:  $net, s^{dl}$**

### 3. Benzetim Sonuçları

DL yardımcı DF çeşitlemeli çok röleli sistemlerde benzetim parametreleri Tablo 1 'de verilmiştir. Tüm programlar Intel Core i9 işlemci ve NVIDIA Quadro P2200 GPU'su bulunan iş istasyonunda çalıştırılmıştır. DL ile seçilen en iyi röle vasıtasıyla yapılan benzetimler, maxmin yöntemine göre bulunan en iyi röle seçim algoritmasıyla yapılan benzetimler ile bit hata oranı (bit error rate-BER) açısından kıyaslanmıştır. Maxmin yöntemiyle bulunan en iyi röle kullanılarak yapılan simülasyonlarda kaynaktan en iyi röleye iletilen güç ile en iyi röleden hedefe aktarılan güç eşit alınmıştır. 3. bölümde anlatıldığı üzere DL  $\eta_1$  veya  $\eta_2$  için iki ayrı ağa göre test edilmiştir. Tüm benzetimlerde kaynak ve hedef arasındaki kanalın varyansı  $\sigma_{sd}^2 = 1$  kabul edilmiştir

**Tablo 1** Benzetim parametreleri.

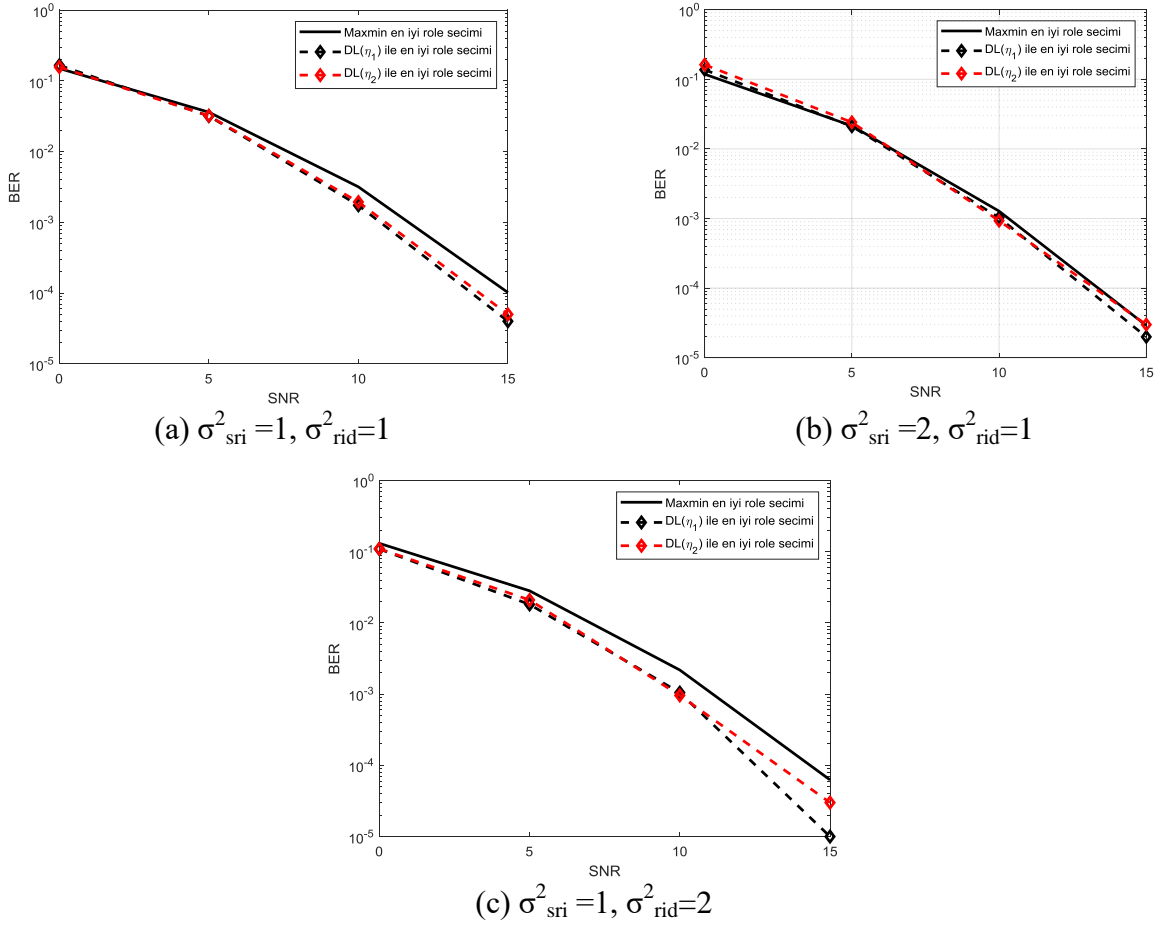
<b>İşbirlikli Çeşitleme Protokolü</b>	<b>DF</b>
Röle Sayısı (N)	4
Kanal Modeli	Rayleigh + AWGN
Kanal Varyansları	$\sigma_{sri}^2 = 1, \sigma_{rid}^2 = 1, \sigma_{sd}^2 = 1$
Modülasyon	BPSK
Eğitim için kullanılan Program	Phyton Tensorflow Kütüphanesi
Veri seti ve simülasyonlar için kullanılan program	MATLAB
Eğitim Örneği Sayısı(S)	$10^7$
Kullanılan DL Modeli	CNN
Epoch Sayısı	5
Mini Grup Boyutu	32
Öğrenme Oranı	0.01
Kayıp Fonksiyonu	CCE
Optimizasyon Algoritması	SGD
Eğitim/Test Oranı	70% / 30%

Şekil 3'te, ortamda  $N=4$  röle olduğu durum için işbirlikli haberleşme ortamdaki benzetim sonuçları verilmiştir. Şekil 3a'da, DL ağının eğitimde kullanılan  $\sigma_{sri}^2 = 1, \sigma_{rid}^2 = 1$  değerleri kullanılarak elde edilen BER eğrileri verilmiştir. Şekilden görüldüğü üzere, DL ile  $\eta_1$  ve  $\eta_2$  için en iyi röle seçim algoritması ile elde edilen BER sonuçları yüksek SNR'lara doğru maxmin ile tespit edilen en iyi röle ile yapılan simülasyonlar ile elde edilen BER sonuçlarından üstündür.  $\eta_1$  ve  $\eta_2$  için DL sonuçları benzerdir. Şekil 3b ve 3c'de ise eğitimde kullanılan kanal varyanslarından farklı değerler için DL ile BER eğrileri elde edilmiştir. DL ile en iyi röle seçimi ile elde edilen BER performansı geleneksel maxmin ile en iyi röle seçim durumundaki BER performansından başarılıdır. İlaveten, Şekil 3c'de en iyi sonucu veren  $\eta_1$  kullanılması durumunda, maxmin ile en iyi seçim algoritmasına göre aynı hata performansı  $\sim 1.5$  -2dB fark ile elde edilmektedir. Şekil 3'te de en iyi sonucu veren  $\eta_1$  durumu için verilen BER eğrilerinin daha iyi olması,  $\eta_1$ 'deki sınıflandırma kolaylığından kaynaklanır. Çünkü  $\eta_1$ 'deki eğitimin  $M=4, K=4, M \times K= 16$  sınıf üzerinden gerçekleşmektedir.



$\eta_2$ 'deki eğitim ise  $M=9$   $K=4$ ,  $M \times K = 36$  sınıf üzerinden gerçekleştirilmektedir. Daha az sınıf olduğu için CNN'in ayırt etme gücü  $\eta_1$ 'de daha yüksektir.

Şekil 4 ve Şekil 5 'te ise sırasıyla ortamda  $N=3$  ve  $N=2$  röle bulunduğu durumlar için benzetimler verilmiştir. Şekil 4 ve Şekil 5'te de Şekil 3'teki benzetimlerdeki benzer etkilerin olduğu açıktır. Eğitimlerde  $N=4$  röle var iken, simülasyonlarda daha düşük röleli sistemlerde yeniden eğitime gerek kalmadan doğrudan eğitilen ağ parametreleri kullanılabilir. Bu durum tasarlanan ağın esnekliğini göstermektedir.



Şekil 3:  $M=4$  röle için benzetim sonuçları

Şekil 4'den görüleceği üzere  $\eta_1$  durumu için yüksek SNR'lara çıkıldıkça BER sonuçları iyileşmeye başlamıştır.  $\eta_1$  için DL ile bulunan BER eğrileri her durumda maxmin ile en iyi röle seçim algoritmasından daha iyi olduğu gözükmektedir. Hata performansı açısından en iyi eğriler  $\eta_1$  ile bulunan DL sonuçları ile Şekil 4c'de bulunmuştur. Şekil 4c'den görüleceği üzere DL ile röle seçim algoritması, maxmin ile en iyi röle seçim algoritmasına ile aynı hata performansı  $\sim 2-2.5$ dB daha az güç ile elde edilebilmektedir.

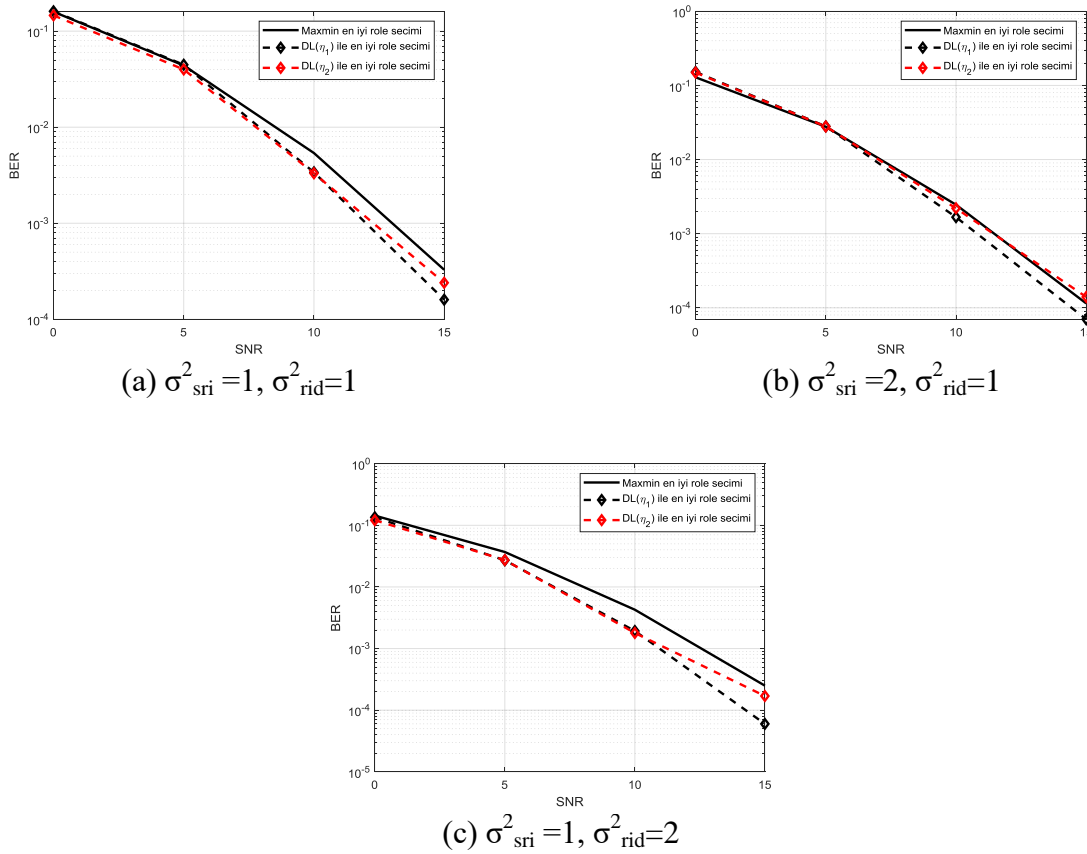
Şekil 5'te  $N=2$  röleli sistemlerde,  $\eta_1$  durumu için elde edilen sonuçlar  $\eta_2$  için elde edilen sonuçlarından belirgin şekilde BER açısından başarılıdır. Şekil 5'teki tüm eğrilerde kanal varyanslarından bağımsız olarak, aynı hata başarımında,  $\eta_1$  için elde edilen sonuçlar  $\eta_2$  için elde edilen sonuçlarından  $\sim 3-4$ dB daha iyidir. Şekil 5c'de ortamda  $N=4$  ve  $N=3$  röle olduğu gibi  $N=2$  röle sayısında da  $\eta_1$  için bulunan sonuçlar maxmin yöntemi ile elde edilen sonuçlardan hata performansı açısından üstündür.  $\eta_1$  için elde edilen hata performansı sonuçları maxmin yöntemine

göre ~2-3dB daha iyidir. Şekil 5'te  $\eta_2$  için verilen eğriler 15dB'ye doğru hata katına uğramaktadır bu durum yine  $\eta_2$  için CNN'in sınıflandırma zorluğundan kaynaklanmaktadır.

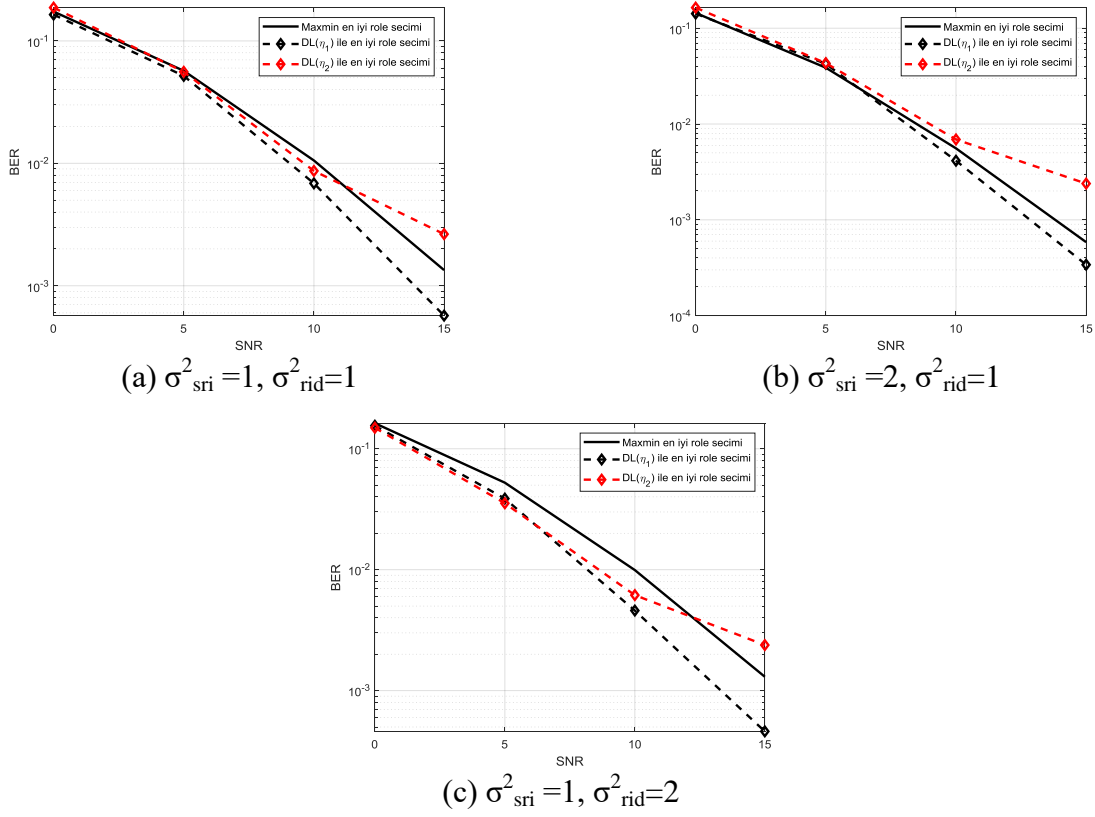
Şekil 6, Şekil 7 ve Şekil 8'de, ortamda  $N=4, 3$  ve  $2$  röle bulunması durumlarında, sırasıyla  $\sigma_{sri}^2=1, \sigma_{rid}^2=1$ ;  $\sigma_{sri}^2=2, \sigma_{rid}^2=1$ ;  $\sigma_{sri}^2=1, \sigma_{rid}^2=2$  kanal varyans değerleri için,  $\eta$  güç paylaşım oranının değişimine ( $\eta=[0.1:0.1:0.9]$ ) göre BER eğrisi verilmiştir. Tüm eğriler SNR=15 dB değeri için elde edilmiştir. Şekil 6, Şekil 7 ve Şekil 8'den görüleceği üzere minimum BER noktalarına hiçbir zaman  $\eta=0.5$ 'te ulaşamamıştır. Bu durum geleneksel maxmin yöntemi ile seçilen en iyi rölede de güç optimizasyonu yapılmasının gerekliliğini göstermektedir. Fakat geleneksel maxmin yöntemi minimum BER değerini veren en iyi röle seçimi için, farklı kanal koşulunda ve röle sayısında,  $\eta$ 'nin tüm değerleri için BER hesaplaması yapılması gerekmektedir. Fakat, DL ile tek seferde ağ çevrimdışı eğitildikten sonra, eğitilen ağ ile çevrimiçi güç optimizasyonlu röle seçimi yapılabilirken minimum BER başarımları elde edilmektedir. Bu durum DL tekniğinin sağladığı önemli bir avantajdır.

#### 4. Sonuç ve Tartışma

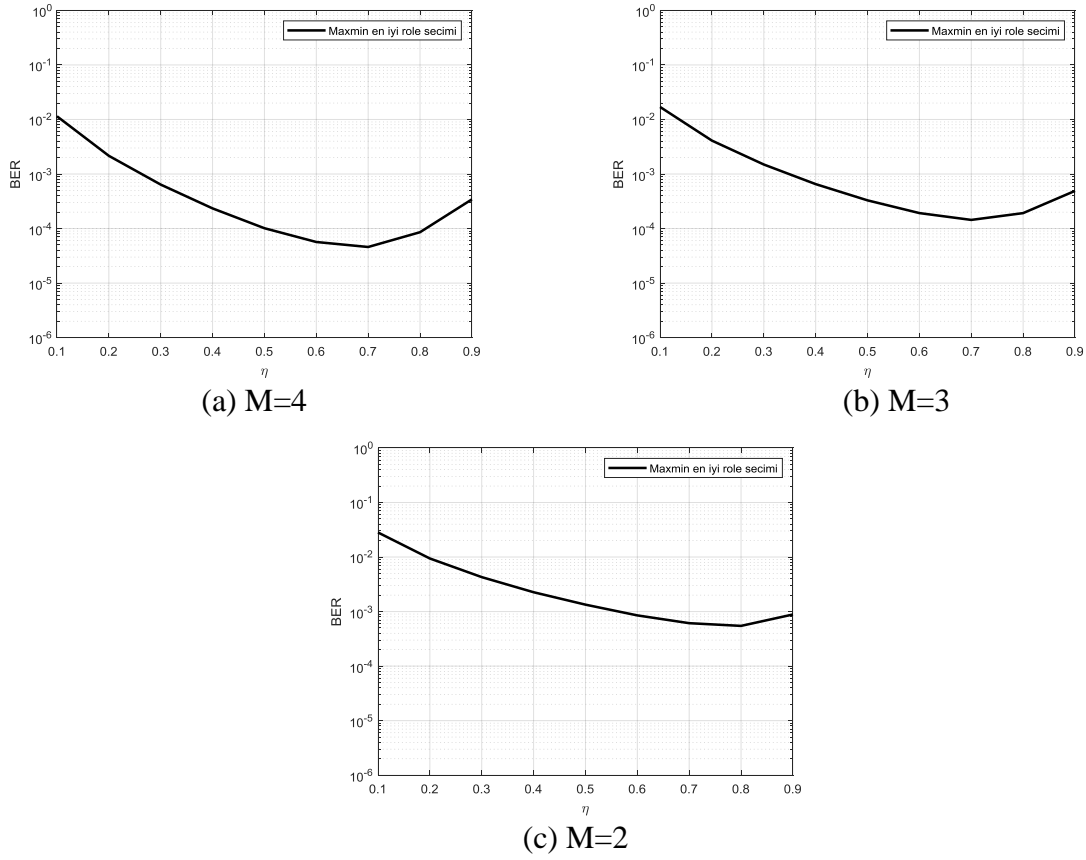
Bu çalışmada ortamda  $N$  adet röle, bir adet kaynak ve hedef düğümün olduğu bir DF protokolü kullanan işbirlikli haberleşme sistemi düşünülmüştür.



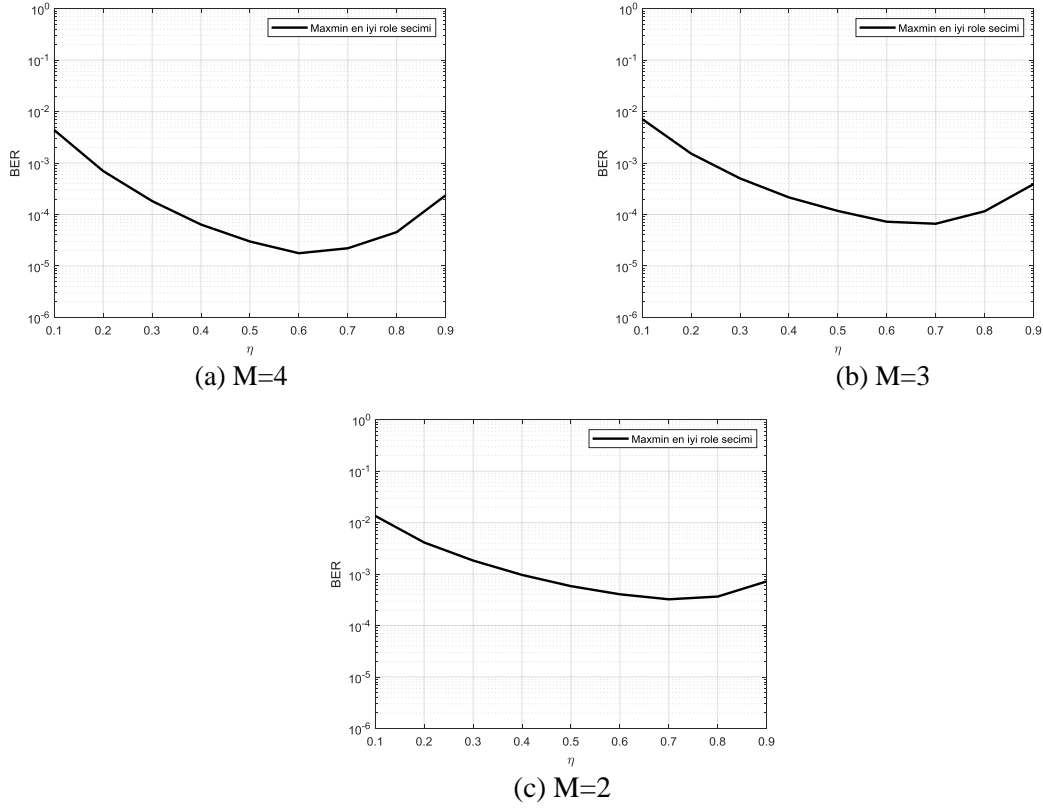
Şekil 4: M=3 röle için benzetim sonuçları



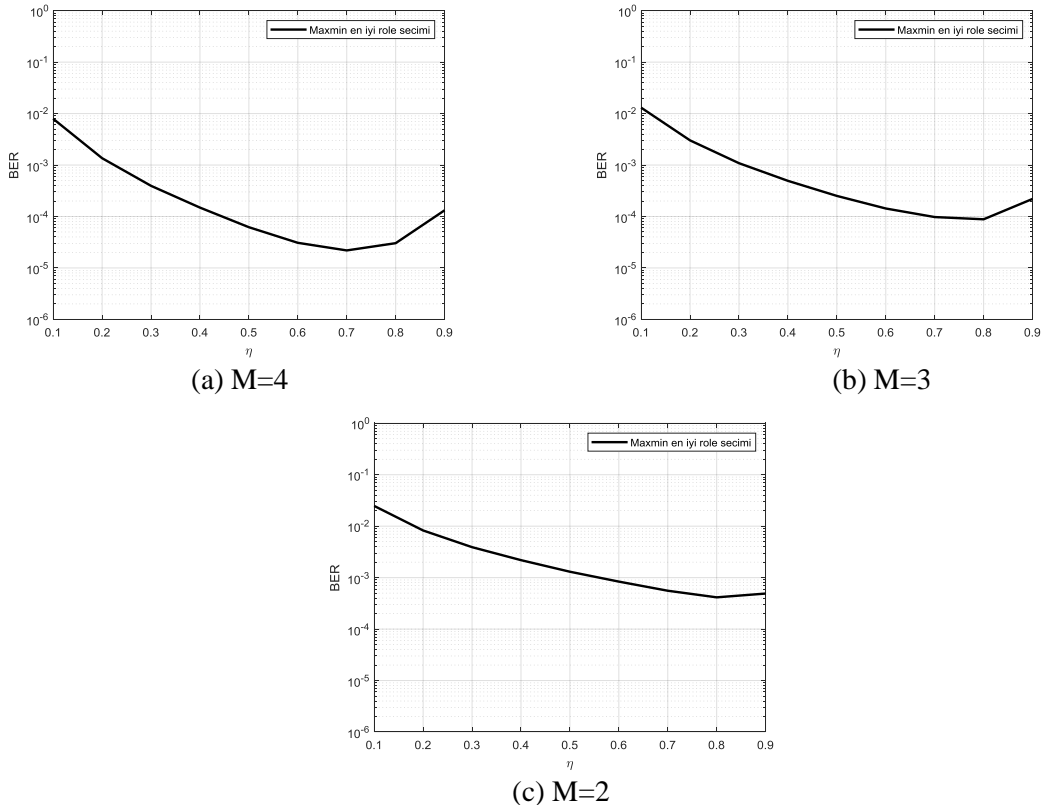
Şekil 5: M=2 röle için benzetim sonuçları

Şekil 6: SNR 15 dB'de  $\sigma_{sri}^2=1, \sigma_{rid}^2=1$  iken maxmin ile en iyi röle seçim algoritması sonuçları

Sistemin spektral verimliliğinin düşürülmemesi amacıyla ortamdaki tüm rölelerin kullanılması yerine içlerinden en iyi link kalitesine sahip röleyi seçerek iletişim yapılabilmektedir. Bu durumda hem röle seçimi hem de kaynak-röle güç paylaşımı için kullanılan optimizasyon yöntemlerinin işlem karmaşıklığı artmaktadır.



Şekil 7. SNR 15 dB'de  $\sigma_{sri}^2=2$ ,  $\sigma_{rid}^2=1$  iken maxmin ile en iyi röle seçim algoritması sonuçları



Şekil 8. SNR 15 dB'de  $\sigma_{sri}^2=1$ ,  $\sigma_{rid}^2=2$  iken maxmin ile en iyi röle seçim algoritması sonuçları

Bu çalışmada, son zamanlarda haberleşme problemlerinin çözümünde kullanılan bir makine öğrenim yöntemi olan DL tekniği kullanılması önerilmiştir. CNN, sınıflandırıcı olarak kullanılan DL algoritmalarından birisidir. Kaynak -i. röle ve i. röle-hedef düğüm arasındaki Rayleigh sönümlenmeli kanal verileri kanal matrisi haline getirilmiştir. Bu kanal matrislerinden CNN yardımcı röle seçim algoritması geliştirilmiştir. Önerilen CNN yardımcı röle seçim algoritmasıyla maxmin en iyi röle seçim algoritması hata başarımı açısından karşılaştırılmıştır. DL yardımcı röle seçiminde güç atama kriteri de göz önünde bulundurulmuştur. Elde edilen sistem hata performansı grafiklerinden, DL yardımcı röle seçim algoritmasının geleneksel maxmin en iyi röle seçimi algoritmasından daha iyi olduğu ortaya konmuştur.

## Teşekkür

2021-75737790-02 kodlu bu proje, Zonguldak Bülent Ecevit Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir. Bu çalışmanın ortaya çıkmasında verdiği destekten ötürü Bilimsel Araştırma Projeleri Birimine teşekkür ederiz.

## Yazar(lar)ın Katkıları

AE programları oluşturdu tasarladı ve makaleyi yazdı. FK fikir önerdi makalenin son halini şekilsel olarak inceledi. HK fikir danışmanlığı, proje yürütücülüğü yaptı.

Yazarlar son halini okudu ve onayladı.

## Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

## Kaynaklar

- [1]. Xiao, Y., Jin, X., Shen, Y., Guan, Q., "Joint Relay Selection and Adaptive Modulation and Coding for Wireless Cooperative Communication", IEEE Sensors Journal, 2021,21(22), 25508-
- [2]. Muenthetrakoon,W., Khutwiang, K., Kotchasarn, C., "SER of Multi-hop Decode and Forward Cooperative Communications under Rayleigh Fading Channel", Second International Conference on Intelligent Systems, Modelling and Simulation, Phnom Penh, Cambodia 318-323,2011.
- [3]. Wang, Y., Zhang, X., Liu, D., "Performance of dual-hop multi-relay cooperative communication system in Rician fading", 6th IEEE International Conference on Software Engineering and Service Science (ICSESS), Beijing, China ,573-577,2015.
- [4]. İkki,S., Ahmed, M., H., "Performance Analysis of Cooperative Diversity Wireless Networks over Nakagami-m Fading Channel", IEEE Commun. Letter,2007, 11(4):334-336.
- [5]. Al-Mistarihi, M., F., Magableh, A. M., Al-Khasawneh, M. M., "Closed form expression of outage probability in DCSK cooperative communication systems over Nakagami-m fading channels", 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Opatija, Croatia,512-515,2015.
- [6]. Lu,H., Hong,P.,Xue, K., "High-Throughput Cooperative Communication with Interference Cancellation for Two-Path Relay in Multi-Source System", IEEE Transactions on Wireless Communications,2013, 12(10): 4840-4851.
- [7]. Bletsas, A., Shin, H.,Win,M. Z., Lippman, A., "A simple Cooperative diversity method based on network path selection," ,IEEE Journal on Selected Areas in Communications, 2006,24(3): 659-672.

- [8]. Ikki S., Ahmed, M. H., "Performance of Multiple-Relay Cooperative Diversity Systems with Best Relay Selection over Rayleigh Fading Channels", 2008, EURASIP Journal on Advances in Signal Processing, Article number: 580368, Open Access, 1-7.
- [9]. Ikki, S., Ahmed, M. H., "On the Performance of Adaptive Decode-and-Forward Cooperative Diversity with the Nth Best-Relay Selection Scheme", IEEE Global Telecommunications Conference, Honolulu, USA, 1-6, 2009.
- [10]. Ikki,S., Ahmed, M. H., "On the Performance of Amplify-and-Forward Cooperative Diversity with the Nth Best-Relay Selection Scheme", IEEE International Conference on Communications, Dresden, Germany, 1-6, 2009.
- [11]. Sanli,E., Kara, F.,Kaya, H., " Hata Yayılımının En İyi Röle Seçimli İşbirlikli Haberleşme Sistemlerinin Hata Başarımına Etkisi" 26th Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU), İzmir,Türkiye, 1-4,2018.
- [12]. Lu, L., He, D., Xie, Q., Li, G.,Y.,Yu, X., "Graph-Based Path Selection and Power Allocation for DF Relay-Aided Transmission," IEEE Wireless Communications Letters,2018, 7(1):138-141.
- [13]. Ho, C. D., Ngo, H. Q., Matthaiou, M., "Pilot Assignment and Power Allocation for Multipair Massive MIMO DF Relaying Networks," IEEE Transactions on Vehicular Technology, 2020,69(7):7379-7388.
- [14]. Saini, R., Mishra, D., Kotha, V., "Power Allocation and Relay Placement for Secrecy Outage Minimization over DF Relayed System", IEEE 18th Annual Consumer Communications & Networking Conference (CCNC), Las Vegas, NV, USA, 1-4, 2021,
- [15]. Kara, F., Kaya, H., "On the Error Performance of Cooperative-NOMA With Statistical CSIT", IEEE Communications Letters,2019, 23(1):128-131.
- [16]. Kara, F., Kaya, H., "Threshold-Based Selective Cooperative-NOMA",IEEE Communications Letters,2019, 23(7):1263-1266.
- [17]. Yang, Y., Bai, Z., Pang, K., Sun, S., Han, T., Kwak, K., "Performance Analysis of SM-Index Modulation Based Cooperative Wireless Communication System", IEEE 18th International Conference on Communication Technology (ICCT), Chongqing, China, 286-290, 2018.
- [18]. Dimas, A., Kalogieras, D. S., Petropulu, A. P., "Cooperative Beamforming With Predictive Relay Selection for Urban mmWave Communications",IEEE Access, 2019,7:157057-157071.
- [19]. Ye, H., Liang, L., Li, G. Y., Juang, B. H., "Deep Learning-Based End-to-End Wireless Communication Systems with Conditional GANs as Unknown Channels", IEEE Transactions on Wireless Communications, 2020,19(5):3133–3143.
- [20]. Ye, H., Li, G. Y., Juang, B. H., "Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems", IEEE Wireless Communications Letters, 2018, 7(1):114–117.
- [21]. Luo, B., Peng, Q., Cosman, P. C., Milstein, L. B., "Robustness of Deep Modulation Recognition under AWGN and Rician Fading," 2018, 52nd Asilomar Conference on Signals, Systems, and Computers, 447-450.
- [22]. Wang,X., Zhang,Y., Shen, R., Xu, Y., Zheng, F.C., "DRL-Based Energy-Efficient Resource Allocation Frameworks for Uplink NOMA Systems", IEEE Internet of Things Journal,2020, 7(8):7279-7294.
- [23]. Wu, N., Wang, X., Lin, B., Zhang, K.,"A CNN-Based End-to-End Learning Framework Toward Intelligent Communication Systems",IEEE Access, 2019,7:110197–110204.
- [24]. Gui, G., Huang, H., Song, Y., Sari, H., "Deep Learning for an Effective Nonorthogonal Multiple Access Scheme",IEEE Transactions on Vehicular Technology,2018, 67(9):8440–8450.
- [25]. Zhang, J., Tao, X., Wu, H., Zhang, N., Zhang, X., "Deep Reinforcement Learning for Throughput Improvement of the Uplink Grant-Free NOMA System", IEEE Internet of Things Journal,2020,7(7):6369–6379.

- [26]. Emir, A., Kara, F., Kaya, H., Yanikomeroglu, H., "DeepMuD: Multi-User Detection for Uplink Grant-Free NOMA IoT Networks via Deep Learning",*IEEE Wireless Communications Letters*, 2021, 10(5):1133-1137.
- [27]. Luong, T. Van, Ko, Y., Vien, N. A., Nguyen, D. H. N., Matthaiou, M., "Deep Learning-Based Detector for OFDM-IM",*IEEE Wireless Communications Letters*, 2019, 8(4):1159–1162.
- [28]. Alrabeiah, M., Alkhateeb, A., "Deep Learning for mmWave Beam and Blockage Prediction Using Sub-6 GHz Channels",*IEEE Transactions on Communications*, 2020, 68(9): 5504–5518.
- [29]. Lu, Y., Cheng, P., Chen, Z., Li, Y., Mow, W. H., Vucetic, B., "Deep Autoencoder Learning for Relay-Assisted Cooperative Communication Systems",*IEEE Transactions on Communications*, 2020, 68(9):5471-5488.
- [30]. Su, Y., Lu, X., Zhao, Y., Huang, L., Du, X., "Cooperative Communications With Relay Selection Based on Deep Reinforcement Learning in Wireless Sensor Networks",*IEEE Sensors Journal*, 2019, 19(20): 9561-9569.
- [31]. Emir, A., Kara, F., Kaya, H., Yanikomeroglu, H., "Deep Learning Empowered Semi-Blind Joint Detection in Cooperative NOMA", *IEEE Access*, 2021, 9:61832-61852.
- [32]. Li, T., Liu, W., Zeng, Z., Xiong, N. N., "DRLR: A Deep Reinforcement Learning based Recruitment Scheme for Massive Data Collections in 6G-based IoT networks", *IEEE Internet of Things Journal (Early Access)*, 2021.
- [33]. Yang H., Xiong, Z., Zhao, J., Niyato, D., Xiao, L., Wu, Q., "Deep reinforcement learning-based intelligent reflecting surface for secure wireless communications",*IEEE Transactions on Wireless Communications*, 2021, 20(1):375-388.
- [34]. Yang H., Alphones, A., Xiong, Z., Niyato, D., Zhao, J. and Wu, K., "Artificial-Intelligence-Enabled Intelligent 6G Networks",*IEEE Network*, 2020, 34(6):272-280.
- [35]. Le Cun et al., "Handwritten digit recognition: applications of neural network chips and automatic learning", *IEEE Communications Magazine*, 1989, 27(11):41-46.